

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **PROBLEM RASPOREĐIVANJA DOSTAVA U PRODAVAONICE KONZUMA**

ZAVRŠNI RAD

Mentor:

Prof. dr. sc. Goran Đukić, dipl. ing.

Student:

Dora Novak

Zagreb, 2019.



SVEUČILIŠTE U ZAGREBU  
**FAKULTET STROJARSTVA I BRODOGRADNJE**



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za završne ispite studija strojarstva za smjerove:  
proizvodno inženjerstvo, računalno inženjerstvo, industrijsko inženjerstvo i menadžment, inženjerstvo  
materijala i mehatronika i robotika

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

## ZAVRŠNI ZADATAK

Student: **Dora Novak**

Mat. br.: 0035204392

Naslov rada na hrvatskom jeziku: **Problem raspoređivanja dostava u prodavaonice Konzuma**

Naslov rada na engleskom jeziku: **Scheduling problem of delivery to Konzum retail stores**

Opis zadatka:

Problem raspoređivanja tjednih dostava po prodavaonicama tvrtke Konzum složen je problem s velikim utjecajem na balans opterećenja u cijelom distribucijskom lancu opskrbe, poglavito operacija u logističkim distribucijskim centrima.

U radu je potrebno:

- dati teorijski pregled upravljanja lancem opskrbe (SCM) s naglaskom na skladištenje i distribuciju,
- dati općenite informacije o Konzumu (lokacija, mikrolokacija, broj prodavaona, gradova i sl.), s naglaskom na opis procesa kreiranja narudžbi u automatskom sustavu naručivanja, prognožiranja prodaje, planiranja ruta dostava, procesa komisioniranja i pripreme robe za dostavu te procesa dostave u prodavaonice,
- teorijski obraditi problem raspoređivanja,
- opisati konkretan problem u dodjeljivanju različitih varijanta rasporeda prodavaonama (rangiranje mogućih varijanti rasporeda, rangiranje prodavaona prema prioritetu, definiranje kriterija optimizacije mogućeg optimizacijskog modela).

Zadatak zadan:

29. studenog 2018.

Zadatak zadao:

Prof.dr.sc. Goran Đukić

Rok predaje rada:

1. rok: 22. veljače 2019.

2. rok (izvanredni): 28. lipnja 2019.

3. rok: 20. rujna 2019.

Predviđeni datumi obrane:

1. rok: 25.2. - 1.3. 2019.

2. rok (izvanredni): 2.7. 2019.

3. rok: 23.9. - 27.9. 2019.

Predsjednik Povjerenstva:

Prof. dr. sc. Branko Bauer

Izjavljujem da sam ovaj rad izradio samostalno koristeći znanja stečena tijekom studija i navedenu literaturu.

Zahvaljujem se mentoru prof. dr. sc. Goranu Đukiću na pruženoj podršci i vodstvu, Adrianu Alajkoviću, direktoru planiranja u lancu opskrbe u Konzumu za iskazano povjerenje, podršku i vrijeme koje je izdvojio za davanje svih potrebnih informacija te Sameru Tomeliehu na velikoj pomoći i konkretnim uputama vezanim uz ovaj rad.

Također se zahvaljujem svojoj obitelji zato što je bila uz mene tijekom cijelog studija, bez čije podrške ne bih mogla ostvariti svoje rezultate.

Dora Novak

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	III
POPIS TABLICA.....	IV
POPIS KRATICA .....	V
SAŽETAK.....	VI
SUMMARY .....	VII
1. UVOD.....	1
2. UPRAVLJANJE LANCEM OPSKRBE .....	2
2.1. Lanac opskrbe .....	2
2.2. Logistika.....	3
2.3. Definicija i ciljevi SCM-a .....	4
2.4. Strategija SCM-a.....	5
3. FIZIČKI TOK MATERIJALA.....	8
3.1. Nabava .....	8
3.2. Obrada narudžbi.....	9
3.3. Skladištenje .....	10
3.4. Rukovanje materijalom .....	11
3.5. Upravljanje zalihama .....	11
3.6. Transport .....	12
3.7. Distribucija.....	13
3.7.1. Kanali distribucije .....	14
3.7.2. Fizička distribucija.....	15
4. PROBLEM RASPOREĐIVANJA .....	17
4.1. Općenito o problemu raspoređivanja .....	17
4.2. Podjela raspoređivanja .....	17
4.3. Problem raspoređivanja u SCM-u.....	17
4.3.1. Glavni raspored proizvodnje.....	18
4.3.2. Problem raspoređivanja dostava u distribuciji .....	20
5. OPIS UPRAVLJANJA LANCEM OPSKRBE U KONZUMU.....	21
5.1. Lokacija i mikrolokacija .....	21
5.1.1. Općenito o poduzeću.....	21
5.1.2. Logističko-distributivni centri.....	21
5.2. Opis procesa SCM-a za dostavu u prodavaonice.....	22
5.2.1. Prognoziranje prodaje .....	22
5.2.2. Opis procesa kreiranja narudžbi u automatskom sustavu naručivanja .....	23
5.2.3. Planiranje ruta dostava .....	24
5.2.4. Proces komisioniranja i pripreme robe za dostavu .....	25
6. LINEARNO PROGRAMIRANJE .....	26
6.1. Grafičko rješavanje linearnog programiranja .....	26
6.2. Simpleks metoda .....	28

6.3. Ograničenja simpleks metode .....	29
6.3.1. Ograničenja tipa $=$ .....	29
6.3.2. Ograničenja tipa $\geq$ .....	29
6.4. Linearno programiranje s cjelobrojnim binarnim varijablama .....	30
7. PROBLEM DODJELJIVANJA RAZLIČITIH VARIJANTI RASPOREDA PRODAVAONICAMA KONZUMA .....	31
7.1. Opis problema .....	31
7.2. Matematičko postavljanje problema .....	32
7.2.1. Ulazni podaci .....	33
7.2.2. Rangiranje mogućih varijanti rasporeda i rangiranje prodavaonica prema važnosti .....	34
7.2.3. Balansiranje količine rada na skladištu .....	35
7.2.4. Izlazni podaci .....	35
7.3. Rješenje problema .....	35
7.3.1. Funkcija cilja .....	35
7.3.2. Ograničenja .....	36
7.3.2.1. Broj dostupnih dana u tjednu za dostavu .....	36
7.3.2.2. Fiksne rute dostava .....	36
7.3.2.3. Intervali između dostava .....	37
7.3.2.4. Rang prodavaonice .....	38
8. ZAKLJUČAK .....	39
LITERATURA .....	40
PRILOZI .....	41

---

**POPIS SLIKA**

Slika 1.	Dijagram aktivnosti i sudionika u lancu opskrbe .....	2
Slika 2.	Pet pokretača lanca opskrbe .....	5
Slika 3.	SCOR model.....	7
Slika 4.	Proces nabave .....	8
Slika 5.	Obrada narudžbi .....	10
Slika 6.	Upravljanje zalihama.....	12
Slika 7.	Povezanost fizičke distribucije i kanala distribucije .....	13
Slika 8.	Mreža distribucijskih kanala .....	15
Slika 9.	Konzumov logističko-distributivni centar.....	22
Slika 10.	ASR sustav .....	24
Slika 11.	Primjer grafičke metode linearnog programiranja .....	27

---

**POPIS TABLICA**

Tablica 1. Definicije SCM-a .....	4
Tablica 2. Responzivnost i efikasnost pokretača SCM-a .....	6
Tablica 3. Primjer MPS-a .....	18
Tablica 4. Primjer rasporeda narudžbi .....	32
Tablica 5. Simulacija vjerojatnosti pojave pojedine stavke u tjednoj narudžbi .....	33

---

**POPIS KRATICA**

SCM – upravljanje lancem opskrbe (engl. *Supply Chain Management*)

SCOR model – engl. *Supply chain operations reference model*

MPS – glavni raspored proizvodnje (engl. *Master Production Schedule*)

ATP – osigurano dostupno (engl. *Available to promise*)

CATP – kumulativno osigurano dostupno (engl. *Cumulative available to promise*)

VRP – problem usmjeravanja vozila (engl. *vehicle routing problem*)

ATP – osigurano dostupno (engl. *Available to promise*)

CATP – kumulativno osigurano dostupno (engl. *Cumulative available to promise*)

LDC – logističko-distributivni centar

ASR – automatski sustav naručivanja (engl. *Automated Stock Replenishment*)

TP – transportno pakiranje

WMS – sustav za upravljanje radom na skladištu (engl. *Warehouse Management System*)



---

**SAŽETAK**

U ovom je radu na temelju teorijskih saznanja o SCM-u i modelu linearnog programiranja postavljen realan problem raspoređivanja dostava u prodavaonice Konzuma. Opisuje se distribucija robe iz logističko-distributivnih centara do prodavaonica te se razmatra mogućnost traženja modela raspoređivanja.

U prvom dijelu rada su opisani ključni procesi SCM-a s fokusom na skladištenje i distribuciju, a razrađen je i problem raspoređivanja u kontekstu logistike. Također se uvodi u logističke procese u Konzumu.

U drugom se dijelu se razrađuje konkretan problem dodjeljivanja rasporeda u matematičkom smislu. Problem vezan za Konzum stavlja se u kontekst linearnog programiranja te se donose određeni zaključci.

**Ključne riječi:**

SCM, skladištenje, distribucija, problem raspoređivanja, Konzum, linearno programiranje, binarno programiranje

---

**SUMMARY**

This paper identifies an actual scheduling problem of delivery to Konzum retail stores on theoretical background of SCM and linear programming model. Given the description of distribution of goods from the logistic distribution centers to the retail stores, possibility of finding an adequate scheduling model is considered.

The first part deals with the SCM key processes, focusing on warehousing and distribution, along with the scheduling problem in the context of logistics. An insight to SCM processes in Konzum is given afterwards.

The second part mostly defines specific scheduling problem in terms of mathematics. Konzum related problem is set within binary integer programming and certain conclusions are made.

Key words:

SCM, warehousing, distribution, scheduling problem, Konzum, linear programming, binary programming

## 1. UVOD

Upravljanje lancem opskrbe (engl. *Supply Chain Management* – SCM) ima sve važniju ulogu u postizanju konkurentnosti na tržištu. To je danas interdisciplinarno područje koje zahtjeva znanje i stručnost u različitim područjima za efikasno rješavanje problema.

SCM obuhvaća velik broj logističkih aktivnosti koje zajedno doprinose efikasnosti i efektivnosti čitavog sustava. U ovom će radu prvo definirati najvažniji pojmovi SCM-a kako bi se što bolje razumio kontekst problema koji će se kasnije detaljnije razraditi.

Problem raspoređivanja (engl. *scheduling*) u distribuciji vrlo je važan aspekt SCM-a zato što nedovoljno dobar raspored može imati posljedice kao što su loše razine zaliha, nepotpuno i neujednačeno korištenje raspoloživih kapaciteta itd. To se sve u konačnici očituje i u padu profita.

Raspoređivanje se koristi u mnogo različiti područja kao što su računarstvo (raspored rada procesora), zdravstvo (raspoređivanje medicinskog osoblja), školstvo (raspored sati) i sl. Opći principi i matematički modeli mogu se primijeniti u svim navedenim područjima. Jednako vrijedi i za SCM te distribuciju.

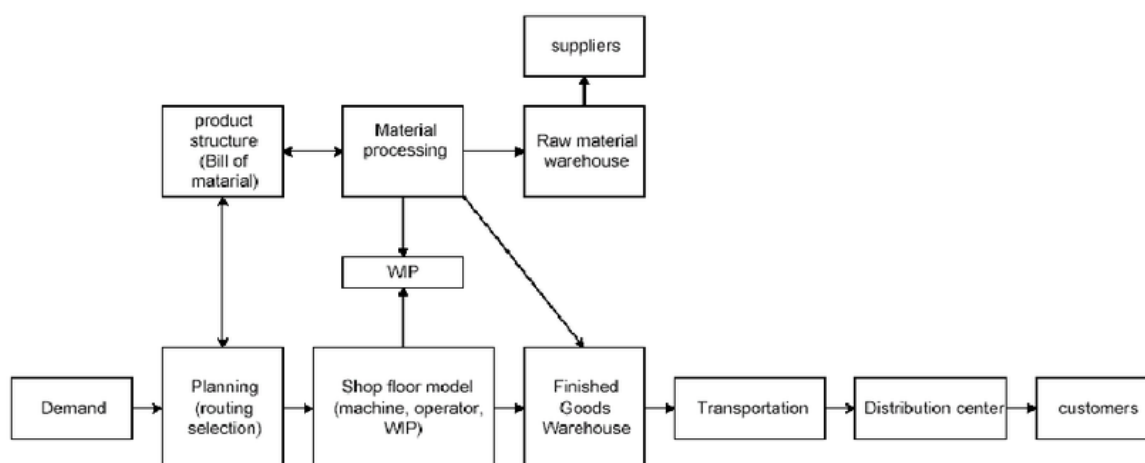
Za razumijevanje i optimiziranje raspoređivanja potrebno je matematički postaviti problem. Problem raspoređivanja se može sagledati u kontekstu linearnog programiranja, stoga je potrebno upoznati se s tim područjem kako bi se ono kasnije moglo iskoristiti za konkretan problem dodjeljivanja rasporeda dostava prodavaonicama Konzuma.

U ovom radu razradit će se problem raspoređivanja dostava u prodavaonice Konzuma pa je bitno upoznati strukturu same tvrtke te način vođenja procesa SCM-a. Za analizu problema definirat će se procesi distribucije u teoriji, isti procesi u Konzumu upoznati s matematičkim modelom. Potrebno je upoznati trenutnu situaciju i jasno definirati ciljeve koji se žele postići optimizacijskim modelom.

## 2. UPRAVLJANJE LANCEM OPSKRBE

### 2.1. Lanac opskrbe

Lanac opskrbe (engl. *supply chain*) je mreža aktivnosti i organizacija koje su uključene u kretanje materijala od izvora do krajnjeg korisnika [5]. Ona povezuje proizvođača s dobavljačima koji omogućuju proizvodnju te s krajnjim kupcima kroz distribuciju proizvoda ili usluga.



**Slika 1. Dijagram aktivnosti i sudionika u lancu opskrbe**

Preuzeto s: [https://www.researchgate.net/figure/Diagram-of-an-example-of-supply-chain-simulation-model-Chang-2001\\_fig6\\_220390140](https://www.researchgate.net/figure/Diagram-of-an-example-of-supply-chain-simulation-model-Chang-2001_fig6_220390140)

Slika 1. prikazuje primjer toka materijala koji prolazi kroz aktivnosti lanca opskrbe. Na ovom primjeru mogu se uočiti dva različita smjera koja polaze od potražnje (engl. *demand*), a to su smjer prema dobavljačima (engl. *suppliers*) i kupcima (engl. *customers*). Na slici su prikazane različite aktivnosti, primjerice skladištenje, transport, distribucija itd.

Lanac opskrbe ima tri segmenta aktivnosti: uzvodne aktivnosti, unutrašnje aktivnosti i nizvodne aktivnosti.

Uzvodne aktivnosti (engl. *upstream*) odnose se na nabavu i dobavljače, unutrašnje (engl. *midstream, internal*) uključuju proizvodnju i sklapanje, dok se nizvodne aktivnosti (engl. *downstream*) bave distribucijom i prodajom krajnjim kupcima. [16]

## 2.2. Logistika

Logistika se definira kao dio procesa lanca opskrbe koji planira, implementira i kontrolira efektivnost i efikasnost tokova materijala te relevantnih informacija od izvora do točke potrošnje, uz zadovoljenje zahtjeva kupaca.

Glavni cilj logistike je osigurati kupcu željeni proizvod ili uslugu u pravo vrijeme na pravom mjestu uz garanciju kvalitete i što nižu cijenu.

Važno je razlikovati pojmove logistike i lanca opskrbe. Logistika je kao dio lanca opskrbe zadužena samo za dio procesa koji se tiče tokova materijala i informacija, dok je lanac opskrbe širi pojam te označava vezu procesa unutar tvrtke kao i onih između tvrtki sa stvaranjem uspješnog poslovnog modela, kojemu je glavni cilj osiguranje tržišne kompetitivnosti.

Logistika treba osigurati određenu razinu efikasnosti i efektivnosti, odnosno responzivnosti. To su dva oprečna pojma.

Efikasnost (engl. *efficiency*) se definira kao izvođenje ili funkcioniranje na najbolji mogući način, sa što manje gubitaka vremena i napora. U smislu logistike efikasnost označava minimiziranje troškova te maksimizaciju profita, uz optimalno raspolaganje dostupnim resursima.

Responzivnost, koja se u literaturi navodi još kao efektivnost, pojam je koji ima značenje brzog odgovora na zahtjeve kupaca te se mjeri razinom zadovoljstva kupaca.

Budući da logističke aktivnosti trebaju zadovoljiti potrebe kupaca uz minimalne troškove, nameće se pitanje odabira optimalnog načina na koji će oba kriterija biti zadovoljena. [17]

### 2.3. Definicija i ciljevi SCM-a

Upravljanje lancem opskrbe (engl. *supply chain management* – SCM), kasnije u tekstu SCM, nema jedinstvenu definiciju budući da se njegova funkcija i opseg djelovanja mijenja kroz vrijeme. Prema [1] navodi se nekoliko značenje SCM-a:

Dubey i Ali (2013.)	SCM može se definirati kao upravljanje uzlaznim i silaznim djelatnostima s dobavljačima i kupcima kako bi se pružila što bolja vrijednost za kupca uz što niže troškove lanca opskrbe.
Machowiak (2012.)	SCM je metodologija optimiziranja poslovnih procesa, čineći ih elastičnijima, agilnijima te naposljetku kompetitivnijima. Glavna funkcija SCM-a je poboljšanje kompetitivnosti proizvoda ili usluge.
Dubey et al. (2012.)	SCM je koncept upravljanja tokom materijala, informacija te sredstava od početka do kraja, tj. od uzlaznih do silaznih članova sustava. Također se bavi odlaganjem materijala nakon upotrebe prema zahtjevima okoliša. SCM nastoji postići sve ciljeve uz najmanje troškove te najveću učinkovitost.
	Izazov SCM-a je identifikacija te implementacija strategija minimiziranja troškova uz istovremeno maksimiziranje fleksibilnosti na sve kompetitivnijem i sve kompleksnijem tržištu.
McCormack i Kasper (2002.)	SCM uključuje procese koji pomažu tvrtki da poboljša svoje kompetencije sinkronizacijom operacija izvora, izrade te dostave proizvoda i usluga, u suradnji s partnerima i dobavljačima.
Harland (1996.)	SCM integrira dvije poslovne funkcije – upravljanje trenutnim odnosima s dobavljačima te integriranje lanca dobavljačevog dobavljača i kupčevog kupca i slično. To je upravljanje povezanih poslova uključenih konačno u proizvode i usluge zahtijevane od krajnjih kupaca.
Council of Supply Chain Management Professionals (CSCMP)	Upravljanje lancem opskrbe (SCM) obuhvaća planiranje i menadžment svih aktivnosti uključenih u opskrbu, pretvorbu i sve logističke aktivnosti. Uključuje kooperaciju i suradnju s partnerima u lancu (dobavljači, posrednici, pružatelji logističkih usluga, korisnici). [5]

**Tablica 1. Definicije SCM-a**

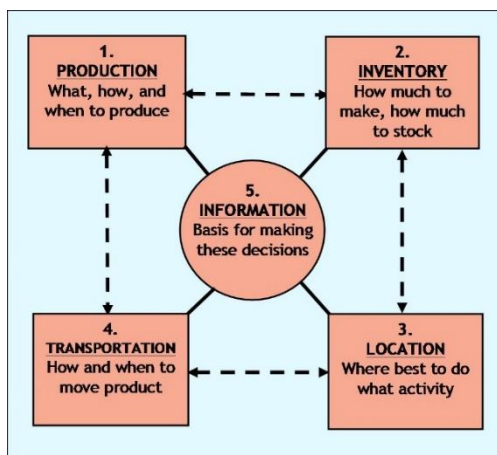
Uz sve navedene definicije danas se upravljanje lancem opskrbe može opisati kao aktivno upravljanje svim aktivnostima lanca opskrbe kako bi se postigla što veća učinkovitost i zadovoljstvo kupaca uz što manje troškove. Cilj je ostvarivanje održivih procesa u aktivnostima SCM-a koje uključuju sve od razvoja proizvoda, preko proizvodnje i logistike pa do informacijskih sustava potrebnih za koordinaciju aktivnosti.

Bitno je naglasiti da se SCM ne bavi samo tokom materijala, već i tokom informacija. Fizički tok materijala uključuje transformaciju, kretanje te skladištenje robe i materijala. On se ujedno smatra i vidljivim dijelom lanca opskrbe. Nevidljivi dio predstavlja tok informacija koji pomaže različitim sudionicima lanca opskrbe u koordinaciji dugoročnih planova te kontroli dnevnih tokova materijala i robe uz i niz lanac opskrbe. [2]

## 2.4. Strategija SCM-a

Upravljanje lancem opskrbe ili SCM ima sve veću važnost u postizanju uspješnog i konkurentnog poslovanja neke tvrtke. Glavni pokazatelj uspješnosti poslovanja u okviru SCM-a je maksimalna učinkovitost uz minimalne troškove. Dobri rezultati postižu se pravilnim strukturiranjem strategije SCM-a.

Za uspješno i učinkovito poslovanje treba se fokusirati na pokretače (engl. *drivers*) lanca opskrbe te razumjeti njihove pozicije u lancu. Njihovo definiranje i odabir omogućuje strukturiranje strategije SCM-a u svrhu optimalnu poziciju lanca opskrbe između efikasnosti i responzivnosti. Prema [3] postoji pet pokretača: proizvodnja, zalihe, lokacija, transport i informacije (Slika 2.).



Slika 2. Pet pokretača lanca opskrbe

Preuzeto s: <https://www.scmglobe.com/five-supply-chain-drivers/>

U Tablici 2. dani su opisi svakog od pokretača u smislu efikasnosti i responzivnosti, na temelju čijeg se izbora izrađuje strategija SCM-a, ovisno o željama i potrebama konkretnog poslovanja [3].


Uzimajući u obzir svih pet pokretača lanca opskrbe potrebno je naći optimalni balans između responzivnosti i efikasnosti, tako da zahtjevi kupaca budu zadovoljeni uz što manje troškove. Odabir ovisi o području djelatnosti, mogućnostima i ciljevima tvrtke.

Pokretači SCM-a	Responzivnost	Efikasnost
PROIZVODNJA	<ul style="list-style-type: none"> <li>• preveliki kapaciteti</li> <li>• fleksibilna proizvodnja</li> <li>• više manjih postrojenja</li> </ul>	<ul style="list-style-type: none"> <li>• veliki kapaciteti</li> <li>• uski fokus</li> <li>• nekoliko središnjih postrojenja</li> </ul>
ZALIHE	<ul style="list-style-type: none"> <li>• visoka razina zaliha</li> <li>• velik raspon artikala</li> </ul>	<ul style="list-style-type: none"> <li>• niska razina zaliha</li> <li>• nekoliko vrsta artikala</li> </ul>
LOKACIJA	<ul style="list-style-type: none"> <li>• puno lokacija blizu kupaca</li> </ul>	<ul style="list-style-type: none"> <li>• nekoliko središnjih lokacija za velika područja</li> </ul>
TRANSPORT	<ul style="list-style-type: none"> <li>• česte dostave</li> <li>• brze i fleksibilne metode</li> </ul>	<ul style="list-style-type: none"> <li>• nekoliko većih dostava</li> <li>• sporije i jeftinije metode</li> </ul>
INFORMACIJE	<ul style="list-style-type: none"> <li>• prikupljanje i dijeljenje pravovremenih i točnih podataka</li> </ul>	<ul style="list-style-type: none"> <li>• trošak informacija pada dok ostali troškovi rastu</li> </ul>

**Tablica 2. Responzivnost i efikasnost pokretača SCM-a**

SCM predstavlja sustav velike kompleksnosti, za koji je potrebno jasno definirati optimalnu poziciju između efikasnosti i responzivnosti. U literaturi se navode različite metode i softveri za rješavanje ovog problema, a jedan od njih je SCOR model (engl. *Supply chain operations reference model*). SCOR model je okvir u kojemu se precizno definiraju svi dijelovi te procesi unutar lanca (Slika 3.). Svako poduzeće nema iste procese pa će se zato i SCOR modeli razlikovati s obzirom na potrebe i način poslovanja određenog poduzeća. [4]






Slika 3. SCOR model [4]

### 3. FIZIČKI TOK MATERIJALA

Uz tok informacija, za upravljanje lancem opskrbe najbitniji je tok materijala. Kao „vidljivi“ dio lanca opskrbe on uključuje sve aktivnosti vezane uz proizvodnju, rukovanje, skladištenje robe i slično. Pojedine logističke aktivnosti bit će objašnjene u radu.

#### 3.1. Nabava

Nabava (engl. *procurement*) je proces opskrbe materijalom i uslugama koje tvrtka treba kako bi uspješno ostvarila svoj poslovni model. Neki od zadataka nabave uključuju budžetiranje, kreiranje narudžbi za dobavljače, pregovaranje o cijeni, kupovinu itd. Kako bi tvrtka ostvarila profit, ukupni troškovi nabave moraju biti manji od iznosa za koji će se gotov proizvod ili usluga kasnije prodati, uključujući sve dodatne troškove izrade i prodaje. [18]



**Slika 4. Proces nabave**

Preuzeto s: <https://www.slideshare.net/riky.kurniawan/scm-smart-spending>

Na Slici 4. su kronološki prikazane aktivnosti unutar procesa nabave:

1. Prepoznati potrebe (engl. *Identify the Need*)
2. Definirati i razraditi potrebe korisnika (engl. *Define & Refine User Requirements*)

3. Utvrditi raspoloživi budžet (engl. *Ascertain the Budget Available*)
4. Saznati što je dostupno na tržištu (engl. *Find out what the market can provide*)
5. Odlučiti se za najbolji proces nabave (engl. *Decide the best process for procurement*)
6. Napraviti ponudu (engl. *Design the Tender*)
7. Skupiti ponuđače (engl. *Tender Exercise*)
8. Sklopiti ugovor (engl. *Contract Award*)
9. Revidirati i zaključiti ugovor (engl. *Contract Managemet/Review and Closure*)

Na početku je potrebno definirati potrebe tako da se uzme u obzir i planirana prodaja. Nakon toga se treba provesti detaljno istraživanje ponuđača na tržištu te uskladiti potrebe i mogućnosti koje dopušta budžet. Nakon odluke o tome što se nabavlja i od koga slaže se ponuda te se u dogovoru s ponuđačima u konačnici potpisuje ugovor o suradnji.

### 3.2. Obrada narudžbi

Logistička aktivnost obrade narudžbi dobiva na važnosti kod velikog broja kupaca te velikog asortimana proizvoda. Ona uključuje proizvođače, distributere i prodajna mjesta. Prodajna mjesta šalju narudžbe, dok proizvođači i distributeri surađuju kako bi isporučili traženu količinu.

Obrada narudžbe odvija se u nekoliko koraka:

- kupac naručuje proizvod
- proizvođač prima narudžbu
- narudžba se obrađuje
- osigurava se zahtijevana količina proizvoda
- narudžba se priprema za transport
- narudžba se šalje kupcu
- kupac zaprima narudžbu koja se dodaje trenutnim zalihama (ukoliko se radi npr. o procesu nabave)

Smanjenje vremena potrebnog za proces obrade narudžbe može pozitivno utjecati na efektivnost cijelog lanca opskrbe. Radi se o logističkoj aktivnosti o kojoj ovise ostale aktivnosti te moguće kašnjenje u obradi narudžbi može rezultirati kašnjenjem ostalih procesa, a samim time i gubitkom profita. [19]

Na Slici 5. figurativno je prikazan proces obrade narudžbi.



**Slika 5. Obrada narudžbi**

Preuzeto s: <https://browntape.com/heres-how-you-can-optimize-order-processing-time/>

### **3.3. Skladištenje**

Prema [5] skladišta su „izgrađeni objekti ili pripremljeni prostori za smještaj i čuvanje roba od trenutka njihovog preuzimanja do vremena njihove upotrebe i otpreme“. Skladište ima dvojnu funkciju – skladištenje i distribuciju, a glavni cilj je prostorno i vremensko uravnoteženje tokova materijala.

Skladištenje označava mirovanje materijala, tj. prekid procesa te na taj način produljuje ciklus proizvodnje, a samim time i povećava troškove. Dobro isplanirani i provedeni procesi skladištenja mogu uvelike utjecati na uspješnost i efikasnost SCM-a.

Kako bi se postigli ciljevi SCM-a, posebnu je pozornost potrebno posvetiti onim aktivnostima i procesima SCM-a koji imaju najveći utjecaj na troškove, kao što su to skladištenje i ostale aktivnosti skladišta. Zbog toga pravilan odabir vrste skladišta i procesa unutar skladišta te mogućnost brzog i fleksibilnog odgovora na zahtjeve kupaca mogu uvelike povećati konkurentnost tvrtke na tržištu. [6]

### **3.4. Rukovanje materijalom**

Rukovanje materijalom uključuje kretanje, kontrolu i zaštitu materijala i gotovih proizvoda kroz čitavi proces proizvodnje, distribucije, potrošnje i odlaganja nakon potrošnje.

Naglasak je na tehničkim sustavima kojima se ostvaruje fizičko manipuliranje, kretanje i pakiranje materijala.

Rukovanje materijala moguće je automatizirati i na taj način skratiti vrijeme potrebno za obavljanje aktivnosti. [5]

### **3.5. Upravljanje zalihama**

U idealnom slučaju upravljanja zaliha one moraju biti što manje, ali istovremeno dovoljne za udovoljavanje potrebama kupaca. Budući da je držanje zaliha veoma skupo, prevelike količine znače nepotrebne troškove, dok premalene količine sirovina, poluproizvoda ili gotovih proizvoda utječu na probleme u proizvodnji i distribuciji. Ravnoteža između dvije krajnosti teško je ostvariva, ali predstavlja optimalno poslovanje te minimalne troškove.

Definiraju se maksimalne, minimalne te optimalne zalihe. Preko definiranog maksimuma se roba više ne nabavlja zbog velikog financijskog opterećenja zadržavanja robe na skladištima, a ispod definiranog minimuma tvrtka ne može pravodobno zadovoljiti potrebe kupaca te samim time ne može uspješno poslovati. Najbolji slučaj je zadržavanje na optimalnoj količini zaliha, tj. to je ona količina robe koja omogućuje redovitu potpunu opskrbu proizvodnje i kupaca, ali uz minimalne troškove skladištenja.

Zalihe koje prelaze optimalnu razinu nazivaju se nekonkurentnima. One predstavljaju smetnju normalnim procesima budući da preopterećuju kapacitet proizvodnje i/ili skladišta, samim time povećavaju troškove te smanjuju efikasnost i rentabilnost poslovanja.

S druge strane, nedostatne zalihe također negativno djeluju na poslovanje uzrokujući zastoje u proizvodnji i distribuciji. Osim direktnog utjecaja na troškove, takve zalihe štete tvrtki i u marketinškom smislu budući da se stvara loš imidž zbog kašnjenja isporuke itd.

Kako bi upravljanje zalihama bilo što uspješnije te pozitivno utjecalo na poslovanje, potrebno je provoditi planiranje zaliha s obzirom na predviđanja potražnje. Procjena potražnje kompleksna je aktivnost koja zahtjeva temeljitu analizu dostupnih podataka i vjerojatnosti mogućih ishoda. [6]

Na slici 6. prikazani su čimbenici koji se trebaju uzeti u obzir kod uspješnog upravljanja zalihama, a to su narudžbe (engl. *Orders*), zalihe (engl. *Inventory*), kanali distribucije (engl. *Multichannel*), analitika (engl. *Analytics*), prognoziranje prodaje (engl. *Forecasting*), obrada narudžbi (engl. *Purchase Orders*), skladišta (engl. *Warehouses*).



**Slika 6. Upravljanje zalihama**

Preuzeto s: <https://www.shopify.com/enterprise/inventory-management-system>

### 3.6. Transport

Transport se kao logistička aktivnost odnosi na kretanje materijala i proizvoda od jedne do druge lokacije, sve od izvora lanca opskrbe pa do krajnjeg kupca.

Transportni sustav je dio logističkog sustava koji ostvaruje sveukupni transportni proces, odnosno ostvaruje kretanje materijala između okoline i poduzeća, unutar poduzeća između pogona, unutar pogona između odjela te unutar odjela između strojeva.

S obzirom na tok materijala postoje unutarnji i vanjski transport. Unutarnji transport zadužen je za unutarnje tokove materijala, dok je vanjski transport zadužen za vanjske tokove.

Sustavi transporta također mogu imati određeni stupanj automatizacije pa se prema tome dijele na [5]:

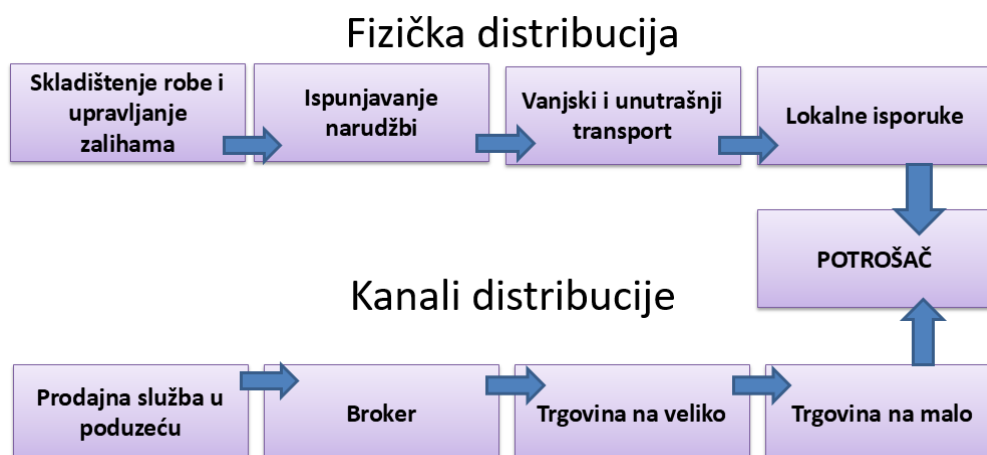
- ručne (manualne) sustave, koji manipuliraju predmetima ručno
- mehanizirane sustave, koji koriste mehaničke uređaje za transport i manipulaciju
- automatizirane sustave, kojima se upravlja pomoću računala

### 3.7. Distribucija

Distribucija je jedna od logističkih aktivnosti u SCM-u, a ujedno je to i koncept koji sadrži već navedene logističke aktivnosti, ali su one u ovom slučaju nizvodne, tj. obuhvaćaju tok materijala od proizvođača prema krajnjem kupcu.

Distribucija ima široko i dinamično područje djelovanja u logistici. Iz gospodarskog aspekta ona označava aktivnosti u svrhu raspodjele proizvodnih dobara potrošačima, dok gledano iz poduzetničkog aspekta distribucija označava marketinšku funkciju koja potpomaže kretanja dobara od proizvođača do krajnjih potrošača [7].

Cilj distribucije je efikasan prijenos dobara od mjesta proizvodnje do mjesta potrošnje, a sve to uz minimalne troškove te zadovoljstvo kupaca. Povećanje efikasnosti uz smanjenje troškova kao cilj čitavog SCM-a može se preslikati na njegove pojedinačne dijelove pa tako i na distribuciju.



**Slika 7. Povezanost fizičke distribucije i kanala distribucije [7]**

Slika 7. prikazuje dvije komponente distribucije, fizičku distribuciju te kanale distribucije, kao i njihovu povezanost preko potrošača. Obje komponente moraju biti osmišljene kako bi distribucija bila uspješno provedena te u konačnici kako bi potrošač dobio željeni proizvod ili uslugu.

### ***3.7.1. Kanali distribucije***

Kanali distribucije su prema definiciji [7] putovi kojim se proizvod premješta od proizvođača do potrošača. Njihova zadaća je olakšati prostornu i vremensku transformaciju dobara na tom putu. Uspješni kanali distribucije osiguravaju dospjeće robe u pravo vrijeme, na pravom mjestu, u odgovarajućim količinama i uz minimalne troškove.

Distribucijski kanali mogu biti kraći ili duži, ovisno o broju posrednika koji sudjeluju u distribuciji proizvoda ili usluge. Roba ili usluge često na putu do krajnjeg kupca prolaze kroz više kanala. Iako veća dostupnost te lakši pristup kupaca određenim proizvodima povećava prodaju, s druge strane stvara kompleksniji sustav upravljanja distribucijskim kanalima. Kanali koji su kraći stvaraju veći profit proizvođačima budući da se troškovi i različite naplate povećavaju proporcionalno dužini.

Na slici 8. prikazane su različite mogućnosti distribucijskih kanala.





### Slika 8. Mreža distribucijskih kanala

Preuzeto s: <https://www.bigly.io/posts/roles-of-distribution-channels-in-the-eCommerce-industry>

### 3.7.2. Fizička distribucija

Fizička distribucija uključuje sva fizička kretanja robe od proizvođača do krajnjeg kupca. Uključuje aktivnosti poput transporta, skladištenja, rukovanja materijalom, upravljanja zalihama, pakiranje, predviđanje potražnje i sl.

Dva su glavna zadatka fizičke distribucije – osiguravanje zadovoljstva kupaca te maksimizacija profita. Zadovoljstvo kupaca se može postići pravovremenom i dovoljnom količinom traženog proizvoda ili usluge na pravom mjestu uz što nižu cijenu. Ukoliko je sve od navedenog osigurano, tvrtka nudeći bolju uslugu po nižoj cijeni zauzima visoko mjesto na tržištu te privlači veći broj kupaca, a samim time povećava profit. Velik utjecaj na maržu profita imaju troškovi fizičke distribucije pa smanjenje istih rezultira porastom profita.

Fizička distribucija ima pet komponenti, a to su [8]:

- obrada narudžbi,
- skladištenje,
- kontrola zaliha,
- rukovanje materijalom,
- transport.

Potrebno je definirati i kontrolirati svaku od navedenih komponenata kako bi ukupni troškovi distribucije bili što manji, a ukupni profit što veći.

## 4. PROBLEM RASPOREĐIVANJA

### 4.1. Općenito o problemu raspoređivanja

Problem raspoređivanja (engl. *scheduling problem*) bavi se što efikasnijom raspodjelom raspoloživih resursa na unaprijed određeni skup zadataka ili procesa, poštujući određena ograničenja. Cilj je optimizirati određene kriterije. Ovisno o području u kojem se rješava problem raspoređivanja moći će se definirati resursi, zadaci ili procesi te ograničenja. [11]

Postoje različite metode rješavanja problema raspoređivanja koje ovise o kompleksnosti zadanog problema. Najčešće se problemi ne mogu riješiti jednostavnim matematičkim postupcima pa se tada primjenjuju heurističke metode koje nude dovoljno dobra rješenja u zadovoljavajućem vremenskom roku.

### 4.2. Podjela raspoređivanja

Postoje dvije vrste raspoređivanja – statičko i dinamičko. [12] Ovisno vrsti zadataka i ograničenja odabiru se metode rješavanja primjerene za određeni problem.

Statičko (engl. *off-line*) raspoređivanje odnosi se na zadatke čije su karakteristike unaprijed poznate pa se raspored može sastaviti prije izvođenja zadataka. Za rješavanje problema ovog tipa raspoređivanja najčešće se koriste metode bazirane na pretraživanju, primjerice genetički algoritmi.

Suprotno statičkom, ukoliko karakteristike zadataka nisu unaprijed poznate, radi se o dinamičkom (engl. *on-line*) raspoređivanju. U ovom slučaju najčešće se koriste heurističke metode. Metode bazirane na pretraživanju ovdje nisu primjenjive zbog vremena koje je potrebno da se pronađu rješenja, a u ovom tipu raspoređivanja često dolazi do trenutnih promjena u sustavu.

### 4.3. Problem raspoređivanja u SCM-u

U upravljanju lancem opskrbe problem raspoređivanja može se primijeniti na više nivoa, u proizvodnji, distribuciji i sl. U svim područjima SCM-a raspoređivanje se radi na temelju predviđanja (engl. *forecasting*).

### 4.3.1. Glavni raspored proizvodnje

Prema [13] glavni raspored proizvodnje (engl. *Master Production Schedule* – MPS), u nastavku MPS, definiran je kao „unaprijed sastavljen i predviđen raspored stavaka za koje je zadužen glavni raspoređivač. MPS predstavlja što i koliko tvrtka planira proizvesti, a taj je plan kvantitativno, određenim specifikacijama i vremenskim rokovima“.

Karakteristike MPS-a su sljedeće [14]:

- srednjoročni planovi
- proizvodne količine po vremenskim intervalima, prema specifičnim konfiguracijama
- integracija između marketinga i proizvodnje (predviđanja prodaje, očekivane narudžbe, vremenski rokovi)

Za izradu MPS-a koriste se različiti ulazni podaci. Glavni ulazni podaci dolaze iz plana proizvodnje, predviđanja za pojedine stavke, stvarnih narudžbi od kupaca ili za nadopunu zaliha, željene razine zaliha pojedinih stavaka te raznih parametara planiranja.

Period	1	2	3	4	5	6	7	8	9	10
Predviđanje potražnje	50	80	20	40	70	100	10	10	10	10
Narudžbe kupaca	40	90	10							
Projicirana dostupnost	150	60	40	0	230	130	120	110	110	90
Osigurano dostupno (Available to promise - ATP)	60									
Kumulativno osigurano dostupno (Cumulative available to promise - CATP)	60	60	60	60	360	360	360	360	360	360
MPS (planirani primitak)					300					
Planirano slanje narudžbi			300							
Stock=200										

**Tablica 3. Primjer MPS-a**

## Izrazi za izračun:

- $\text{Projicirana dostupnost} = \text{dostupne zalihe} + \text{MPS} - \max(\text{predviđanje potražnje, narudžbe kupaca})$
- $\text{ATP za prvi period} = \text{dostupne zalihe} + \text{MPS} - \text{narudžbe kupaca do sljedećeg MPS}$
- $\text{ATP za sve sljedeće periode} = \text{MPS} - \text{narudžbe kupaca do sljedećeg MPS}$

Tablica 3. prikazuje primjer jednog MPS-a. Uzeti su u obzir parametri predviđanja potražnje, narudžbi kupaca te količini dostupnih stavaka. Na početku se treba izvršiti podjela na periode za koje će se pojedinačno izračunavati prodaja te razina zalihe. Prije prvog perioda količina zaliha iznosi 200 komada, a za prvi je period predviđena potražnja od 50 komada, dok je stvarnih narudžbi bilo 40. Prema izrazu za izračun projicirane dostupnosti ona će za prvi period iznositi 150. Kod računanja projicirane dostupnosti uzima se u obzir veća vrijednost između predviđene potražnje i narudžbi kupaca budući da je to nije stvarna situacija, već 'najgori' slučaj. Osigurano dostupno (engl. *available to promise* – ATP) komada označavat će onu količinu proizvoda koja se je dostupna za prodaju u tom periodu, nakon što se od trenutnih zaliha odbije količina u narudžbi za sljedeći period. U ovom slučaju ona iznosi  $150 - 90 = 60$ . Kod računanja ATP-a za svaki sljedeći period pretpostavlja se da je čitav ATP za prošli period već prodan. Zato se gleda samo primitak nove količine proizvoda, od koje se ponovno odbija planirana narudžba za sljedeći period. Kod izračuna CATP-a se pretpostavlja da ATP prošlog perioda nije prodan pa je i dalje na raspolaganju. Računa se kumulativni zbroj ATP-ova i primitaka, s time da se i on umanjuje za planirane narudžbe u sljedećem periodu. Budući da za prvi period ATP iznosi 60, CATP će također iznositi 60 do prvog primitka od 300 komada, kada će on narasti na 360.

Ovakav tip prikaza vrlo je jednostavan i pregledan za planiranje prodanih i dostupnih stavaka u određenom vremenskom periodu podijeljenom na manje intervale. Uzimajući u obzir stvarnu i predviđenu potražnju mogu se napraviti i usporedbe između istih.

#### 4.3.2. Problem raspoređivanja dostava u distribuciji

Postoje tri vrste dostave: individualna (engl. *individual delivery*), direktna serijska (engl. *direct batch delivery*) i usmjerena serijska dostava (engl. *routing batch delivery*), koja se još naziva i usmjerena dostava vozilima (engl. *vehicle routing delivery*). Individualna dostava označava pojedinačnu dostavu svakom kupcu, a direktna serijska dostava razlikuje se samo u količini dostavljene robe, budući da se radi o serijskoj isporuci, ali još uvijek ciljano samo jednom kupcu, odnosno na jedno odredište. U ovom radu najviše će biti riječi o posljednjoj vrsti dostave, tj. o dostavi vozilima po rutama. Radi se o zajedničkoj isporuci robe na različita odredišta prema predodređenom planu, tj rasporedu ruta.

Kada se planiraju rute dostava, trebaju se uzeti u obzir različiti kriteriji koji mogu biti primjerice kapaciteti, udaljenosti, rokovi isporuke i slično. Idealno napravljene rute u optimalnom bi omjeru trebale zadovoljiti sve postavljene kriterije.

Klasični problem usmjeravanja vozila (engl. *vehicle routing problem* – VRP) ima zadatak definirati rute za vozila na raspolaganju, uzimajući u obzir sva postavljena ograničenja i prioritete. VRP se klasificira kao NP-teški<sup>1</sup> problem, a postoji veći broj dostupnih algoritama i heurističkih metoda za njegovo rješavanje. Naravno, za svaki je problem potrebno odabrati onu metodu koja će najbolje zadovoljiti njegove ciljeve. [15]

---

<sup>1</sup> NP-teški problemi predstavljaju klasu problema u računarstvu koja se definira kao nedeterministički polinomijalni problemi.

## **5. OPIS UPRAVLJANJA LANCEM OPSKRBE U KONZUMU**

### **5.1. Lokacija i mikrolokacija**

#### **5.1.1. Općenito o poduzeću**

Puni naziv poduzeća je KONZUM trgovina na veliko i malo dioničko društvo, a skraćeno se najčešće koristi samo KONZUM d.d. Sjedište poduzeća je u Zagrebu, u Ulici Marijana Čavića 1a. Pravni oblik poduzeća je dioničko društvo s ukupno 22 702 860 dionica.

Konzum u Hrvatskoj broji oko 600 prodajnih mjesta koja se nalaze u 114 gradova i 211 mjesta, uključujući hrvatske otoke. Postoje tri prodajna formata robe široke potrošnje: U susjedstvu, Maxi i Super. [9]

Broj prodavaonica nije konstantan, a razlozi promjene najčešće ovise o potražnji. Primjerice, postoje prodavaonice koje rade sezonski pa su tako otvorene samo u ljetnim mjesecima. Također, stalno se otvaraju neke nove i zatvaraju neke stare prodavaonice, ali njihov broj trenutno varira oko 600.

#### **5.1.2. Logističko-distributivni centri**

Konzum raspolaže s dva logističko-distributivna centra (LDC) u Zagrebu i Splitu. LDC Dalmatina u Dugopolju kod Splita opskrbljuje robom prodavaonice u Dalmaciji, dok onaj u Zagrebu na Žitnjaku pokriva ostatak Hrvatske – Istru, Kvarner, Zagorje, Slavoniju itd.

Logističko-distributivni centar Žitnjak – LDC II ima ukupnu površinu od 52 257 m<sup>2</sup>, a LDC Dalmatina trenutno je najveći LDC u regiji s površinom preko 80 000 m<sup>2</sup>. [10]

Postoje različiti lanci opskrbe za svježu, smrznutu i ambijentalnu robu budući da te tri vrste robe imaju različite uvjete skladištenja. Zbog toga se svi procesi SCM-a trebaju definirati za svaki lanac opskrbe pojedinačno.

Na Slici 9. prikazana je zgrada Konzumovog logističko-distributivnog centra na Žitnjaku.



**Slika 9. Konzumov logističko-distributivni centar [10]**

## **5.2. Opis procesa SCM-a za dostavu u prodavaonice**

### **5.2.1. Prognoziranje prodaje**

Prognoziranje ili procjena prodaje (engl. *forecasting*) osnova je za ostale dijelove procesa kojima je krajnji cilj dostava zahtijevane količine proizvoda, tj. artikala u prodavaonice.

Zadatak procjene prodaje je odrediti količinu zaliha prema potrebama pojedinih prodavaonica. Osim troška koji se povećava proporcionalno s veličinom zaliha zbog skladištenja, otpisa robe i sl., kod prevelikih zaliha smanjuje se kvaliteta raspoložive robe, primjerice kod svježih robe. S druge strane, ukoliko u prodavaonici nema dovoljno zaliha, to će se odraziti na ukupnom profitu budući da su kupcima proizvodi nisu dostupni u dovoljnim količinama pa će tako i manje potrošiti.



Procjena prodaje u Konzumu radi se na temelju povijesnih podataka od zadnje dvije godine. Prognoza se radi za narednih 15 tjedana. To su velike baze podataka koje su posložene po prodavaonicama, šiframa artikala te procjenama količine prodaje određenog artikla u komadima. Artikl je oznaka za pojedini proizvod, a kombinacija, tj. veza artikla i prodavaonice naziva se stavka.

Procjene prodaje se koriste za sve daljnje procese SCM-a te je iznimno važno je pripremiti što točnije procjene prodaje kako stvarna prodana i procijenjena količina ne bi jako varirale.

### **5.2.2. Opis procesa kreiranja narudžbi u automatskom sustavu naručivanja**

Konzum koristi automatski sustav naručivanja (engl. *Automated Stock Replenishment* – ASR) u kojem se prema određenim zahtjevima kreiraju automatske narudžbe. Potrebno je da svaka prodavaonica u svakom trenutku ima dovoljnu količinu zaliha.

Količina zaliha određuje se prema procjenama prodaje za svaki dan. Automatska narudžba treba podatke o količini potrebnih transportnih pakiranja (TP) za određeni artikl u određenoj prodavaonici. Te podatke koristi za kreiranje stavaka, tj. odluku hoće li će se u automatskoj narudžbi pojaviti određeni artikl ili ne.

Svaki artikl ima predodređeni broj komada proizvoda koji čine jedno transportno pakiranje. Primjerice, ako za proizvod A TP sadrži 12 komada, a procjena prodaje za taj dan u prodavaonici X iznosi 1750 komada proizvoda A, u automatskoj će se narudžbi kreirati 145,8 TP. To znači da se u prodavaonicu X za taj dan treba poslati 146 TP proizvoda A, tj. s obzirom na već postojeće zalihe prodavaonice X računa se razlika koju je potrebno nadoknaditi automatskom narudžbom. Isporuke se vrše samo radnim danima, od ponedjeljka do petka pa se procjene prodaje trebaju prilagoditi tome kako bi se kreirale automatske narudžbe.

Budući da se radi o velikom broju prodavaonica i različitih artikala koji se dopremaju s jednog velikog centralnog skladišta, broj kreiranih automatskih narudžbi na dnevnoj bazi također je velik. Zato je bitno da ASR sustav bude u velikoj mjeri automatiziran i jednostavan.



**Slika 10. ASR sustav**

Preuzeto s: <https://amywy.wordpress.com/2014/03/24/merchandise-continuous-replenishment-retail-pricing-edlp-retail-social-media/>

Na slici 10. figurativno su prikazani procesi uključeni u ASR sustav. Nakon analize podataka i napravljene procjene prodaje, distribucijski centar definira i dostavlja određenu količinu robe u prodavaonice, iz kojih se šalju podaci o razini zaliha i stvarnoj prodaji. Ti se podaci ponovno obrađuju te se cijeli proces odvija otpočetka.

### 5.2.3. Planiranje ruta dostava

Konzumove prodavaonice raširene su po cijeloj Hrvatskoj, a postoje samo dva logističko-distributivna centra, planiranje ruta dostava ima prilično važnu ulogu u cijelom procesu distribucije.

S obzirom na potrebe, Konzum ima usmjerenu dostavu vozilima (engl. *vehicle routing delivery*) tako što jedno vozilo obilazi nekoliko prodavaonica u jednom danu.

Rute su definirane tako da se dostava u određene dijelove Hrvatske vrši određenim danima u tjednu. Primjerice, dostava u Zagorje može biti moguća ponedjeljkom, utorkom i četvrtkom. Rute dostave u prodavaonice Konzuma su fiksne te se moraju uzeti u obzir u trenutku kreiranja automatske narudžbe. Samim time one predstavljaju jedno od ograničenja kod raspoređivanja dostava.

---

**5.2.4. Proces komisioniranja i pripreme robe za dostavu**

Nakon što se u sustavu za automatsku narudžbu (ASR) kreira automatska narudžba, ona se šalje u sustav za upravljanje radom na skladištu (engl. *Warehouse Management System* – WMS). Narudžbe su WMS-u postaju radni nalozi. Velike automatske narudžbe razbijaju se na više manjih radnih naloga tako da slični proizvodi budu na istim transportnim jedinicama. Na taj se način osigurava jednostavniji proces dostave u prodavaonice.

WMS je koncipiran da vodi komisionera po skladištu uz upute koliko kojeg proizvoda treba komisionirati. Komisioneri, dakle, dobiju radni nalog u ručnom terminalu, koji ih na efikasan način vodi od lokacije do lokacije na skladištu uz upute o količini i lokaciji proizvoda.

Nakon komisioniranja roba odlazi na otpremnu zonu, gdje je preuzimaju transporti koji prema predodređenim rutama obavljaju dostavu po prodavaonicama.

## 6. LINEARNO PROGRAMIRANJE

Problem raspoređivanja može se postaviti kao problem u području linearnog programiranja. Linearno programiranje [11] je vrsta matematičkog programiranja koje ima za cilj maksimizirati, odnosno minimizirati funkciju cilja uz zadovoljenje svih ograničenja:

**min/max  $f(\mathbf{x})$**

uz:

$$g_i(\mathbf{x}) \leq 0; \quad i = 1, 2, 3, \dots, m$$

$$h_j(\mathbf{x}) = 0; \quad j = 1, 2, 3, \dots, k,$$

gdje je  $\mathbf{x}$  n-dimenzionalni vektor s komponentama  $x_1, x_2, \dots, x_n$ , a  $f, g_1, \dots, g_m$  i  $h_1 \dots h_k$  su funkcije definirane u n-dimenzionalnom euklidskom prostoru, dok su u linearnom programiranju i funkcija cilja i ograničenja linearne funkcije od  $\mathbf{x}$ .

Optimalnim rješenjem smatra se ono rješenje u kojemu je funkcija cilja maksimalna. Standardni zapis je sljedeći:

$$\max z = \sum_{j=1}^n c_j \cdot x_j,$$


uz ograničenja:

$$\sum_{j=1}^n a_{ij} \cdot x_j \leq b_i; \quad i = 1, \dots, m$$

$$x_j \geq 0; \quad j = 1, \dots, n$$

### 6.1. Grafičko rješavanje linearnog programiranja

Grafička metoda može se primijeniti samo kod izrazito jednostavnih problema koji imaju samo dvije varijable. U realnim problemima ona gotovo i nema primjenu budući da se najčešće rješavaju kompleksniji viševarijabilni slučajevi, no ova metoda se može koristiti kao vizualizacija drugih metoda rješavanja.



**Slika 11. Primjer grafičke metode linearnog programiranja**

Na Slici 11. prikazan je primjer rješenja problema linearnog programiranja grafičkom metodom. Funkcija cilja koja se maksimizira u ovom slučaju je zadana kao  $\max z = 3x_1 + 5x_2$ ,

$$\begin{aligned} x_1 &\leq 4 \\ 2x_2 &\leq 12 \\ 3x_1 + 2x_2 &\leq 18 \end{aligned} \quad , \text{ uz tri ograničenja te } x_1 \geq 0, x_2 \geq 0.$$

Rješenje je maksimalni iznos funkcije cilja, kada se gleda presjek rješenja s obzirom na zadana ograničenja. [11]

## 6.2. Simpleks metoda

Simpleks metoda trenutno je najraširenija metoda rješavanja različitih problema linearnog programiranja. [11]

Na početku se standardni oblik linearnog programa treba prilagoditi ovoj metodi. U svaku se nejednadžbu uvodi dopunska varijabla koja predstavlja razliku između lijeve i desne strane ograničenja i dobiva se sljedeći oblik:

$$\begin{aligned} \max z &= \sum_{j=1}^n c_j \cdot x_j \\ \sum_{j=1}^n a_{ij} \cdot x_j + x_{n+i} &\leq b_i; \quad i = 1, \dots, m \\ x_j &\geq 0; \quad j = 1, \dots, n \end{aligned}$$

Simpleks metoda iterativni je postupak koji traži rješenja tako da ona u svakom sljedećem koraku imaju veću vrijednost funkcije cilja od rješenja u prethodnom koraku, uz stalno zadovoljavanje jednadžbi i uvjeta nenegativnosti.

Kod simpleks metode varijable se mogu podijeliti na bazične i nebazične varijable. Nebazične varijable su skup varijabli kod kojih se njihova vrijednost fiksira na nulu, a bazične varijable su one čija se vrijednost računa i u pravilu je različita od nule. U svakom koraku postupka jedna od nebazičnih varijabli mijenja se u bazičnu i obrnuto. Nebazična varijabla koja poprima pozitivno rješenje naziva se ulaznom nebazičnom varijablom zato što se kaže da ona *ulazi u bazu*. S druge strane, bazična varijabla čija vrijednost poprima nulu naziva se izlaznom bazičnom varijablom jer ona *izlazi iz baze*.

Premještanjem linearnog programa iz jednog bazičnog rješenja u drugo pokušava se doći do optimuma. Na početku je potrebno pronaći početno bazično rješenje od kojeg se kreće. Najčešće se strukturne varijable proglašavaju nebazičnim, a dopunske varijable bazičnim, a njihove se vrijednosti očitavaju iz desnih strana ograničenja.

U svakom koraku simpleks metode potrebno je odabrati ulaznu nebazičnu varijablu čiji će jedinični porast najviše povećati funkciju cilja te izlaznu bazičnu varijablu koja će porastom ulazne prva pasti na nulu. Ukoliko se ne može odabrati ulazna nebazična varijabla koja će povećati funkciju cilja, simpleksni postupak se prekida.

### 6.3. Ograničenja simpleks metode

Inače je simpleks metoda prilagođena ograničenjima tipa  $\leq$  te se u tom slučaju jednostavno dodaju dopunske jednadžbe te se lako očitava početno bazično rješenje. U slučajevima ograničenja tipa  $\geq$  ili  $=$  postupak postaje kompliciraniji. [11]

#### 6.3.1. Ograničenja tipa $=$

Kod ograničenja tipa  $=$  ne dodaje se dopunska varijabla, ali se početno bazično rješenje ne može lako očitati. Zato se dodaje umjetna varijabla, a ograničenje se iz:

$$\sum_{j=1}^n a_{ij} \cdot x_j = b_i$$

modificira u:

$$\sum_{j=1}^n a_{ij} \cdot x_j + \overline{x_{n+1}} = b_i$$

U konačnom je rješenju potrebno da vrijednost umjetne varijable padne u nulu jer u suprotnome modificirano ograničenje neće vrijediti.

#### 6.3.2. Ograničenja tipa $\geq$

Kod ograničenja ovog tipa, nejednadžba se pretvara u jednadžbu oduzimanjem dopunske varijable, no ni u ovom se slučaju početno bazično rješenje ne može očitati. Stoga je potrebno dodati umjetnu varijablu.

Tako će se ograničenje:

$$\sum_{j=1}^n a_{ij} \cdot x_j \geq b_i$$

modificirati u:

$$\sum_{j=1}^n a_{ij} \cdot x_j - x_{n+1} + \overline{x_{n+2}} \geq b_i$$

I u ovom je slučaju za konačno rješenje potrebno osigurati da umjetna varijabla poprimi vrijednost nule.

#### 6.4. Linearno programiranje s cjelobrojnim binarnim varijablama

Ukoliko je potrebno donijeti odluku tipa Da/Ne, takav se problem može riješiti linearnim programiranjem, točnije cjelobrojnim binarnim programiranjem (engl. *binary integer programming*). Varijable tada mogu poprimiti samo vrijednosti 0 i 1, a nazivaju se binarnim varijablama.

Binarno linearno programiranje služi za optimizaciju raznih problema uključivanjem i isključivanjem slučajeva (0 i 1). Dakle, u binarnom linearnom programiranju varijable su kombinacije slučajeva programa.

Linearni program s  $n$  binarnih varijabli ima  $2^n$  mogućih rješenja. To znači da za 10 binarnih varijabli postoji 1024 rješenja, dok za 50 varijabli postoji  $1,125 \times 10^{15}$  mogućih rješenja. Vidljivo je da broj različitih rješenja raste eksponencijalno pa je najbolje rješenje moguće naći samo za manji broj binarnih varijabli. [11]



## **7. PROBLEM DODJELJIVANJA RAZLIČITIH VARIJANTI RASPOREDA PRODAVAONICAMA KONZUMA**

### **7.1. Opis problema**

Dodjeljivanje različitih varijanti rasporeda prodavaonicama Konzuma trenutno se obavlja na temelju iskustva i ljudske procjene optimalnog rješenja. Takav način dodjeljivanja rasporeda zadovoljava potrebe za zalihama pojedinih prodavaonica, no njime nije omogućena optimalna dodjela rasporeda te optimalna raspodjela rada na skladištu.

U svrhu optimizacije već spomenutih procesa potrebno je napraviti algoritam koji će na temelju procjena prodaje automatski generirati rasporede narudžbi po danima na tjednoj bazi, uz zadovoljenje određenih kriterija: broj stavki, broj TP, rang prodavaonica prema važnosti, usklađivanje s fiksnim rutama dostava i sl.

Rješenje ovog problema donijelo bi brojna poboljšanja u sustavu distribucije Konzuma. Upravljanje radom na skladištu bilo bi uspješnije i to tako da ne varira više od  $\pm 10\%$ . To znači da bi količina rada na skladištu bila konstantna i ujednačena, tj. svi dani bi bili podjednako opterećeni, a samim time bi se povećala i funkcionalnost skladišta. Sama kontrola varijabilnosti rada bila bi bolja. Uz to, raspodjela isporuka omogućila bi važnijim prodavaonicama bolju varijantu dostave. Troškovi otpisa robe bi se na taj način smanjili, kao što bi se smanjila i razina zaliha, a važniji dućani raspolagali bi s 'boljom' i svježijom robom.

Ovim rješenjem također bi se otklonili neki postojeći rizici. Budući da se radi o procesima koji se trenutno temelje na ljudskom iskustvu, a danas je u industriji vrlo brza cirkulacija ljudi koji mijenjaju radna mjesta, u slučaju njihovog odlaska bi se izgubio velik dio znanja potrebnog za ovaj zadatak. Iako je postojeće rješenje zadovoljavajuće u razdoblju uobičajenog prometa i ustaljenih rasporeda dostava, problem nastaje u razdobljima blagdana i povećane prodaje, tj. u razdobljima kada se trebaju kreirati novi rasporedi. Zbog velike količine podataka i ograničenja koja se trebaju uzeti u obzir kod dodjele rasporeda dostava nastaju poteškoće. Promjene rasporeda stvaraju velik obujam posla koji se želi izbjeći upravo kreiranjem algoritma koji bi efikasno funkcionirao za sve razine prodaje.

## 7.2. Matematičko postavljanje problema

Problem dodjele rasporeda prodavaonicama se u stvari može riješiti kao problem linearnog programiranja s cjelobrojnim binarnim varijablama. Varijable su u ovom slučaju dani u tjednu na raspolaganju za dostavu: ponedjeljak, utorak, srijeda, četvrtak i petak. Svaki dan može poprimiti vrijednost ili 0 ili 1, tj. taj dan će se ili obaviti dostava u određenu prodavaonicu (1) ili neće (0).

Potrebno je maksimizirati funkciju cilja, odnosno varijante rasporeda s obzirom na njihov rang uz zadovoljenje postavljenih ograničenja. Za svaku prodavaonicu određen je broj narudžbi u tjednu pa se s obzirom na to kreiraju različite varijante. Budući da se radi o kombinacijama, broj mogućih varijanti će biti:

$\binom{n}{k}$ , tj. u ovom slučaju  $\binom{5}{x}$ ,

- $n$  – broj dana u tjednu raspoloživih za dodjeljivanje rasporeda; u ovom slučaju to će uvijek biti 5 (od ponedjeljka do petka)
- $k$  – potrebni broj narudžbi tjedno; u ovom slučaju  $x$  označava taj broj.

Primjerice, za dvije narudžbe tjedno postojat će 10 različitih varijanti, dok će za četiri narudžbe tjedno postojati njih 5.

Svakoj varijanti dodijeljen je rang koji odgovara kvaliteti određene varijante. Uvijek će biti bolja ona varijanta kod koje se dostave vrše u ujednačenim intervalima, tj. da između svake dostave prođe otprilike jednak broj dana.

U Tablici 4. prikazan je primjer dodjele rasporeda, u kojem je svakoj prodavaonici dodijeljena ona varijanta koja će osigurati što bolji rang te ujednačen rad na skladištu po danima, što se može vidjeti iz sumiranih narudžbi po danima.

	Prodavaonica						Broj narudžbi tjedno	Varijanta	Rang
	↓						↓	↓	↓
Dani u tjednu →		Ponedjeljak	Utorak	Srijeda	Četvrtak	Petak			
	1	0	0	1	0	1	2	V12	5
	2	0	1	0	0	0	1	V70	15
	3	1	0	1	0	1	3	V1	1
	4	0	0	0	1	0	1	V86	18
	5	0	1	0	0	1	2	V27	8
	6	1	0	1	0	0	2	V32	9
	7	1	0	1	1	0	3	V7	3
	8	0	1	0	1	0	2	V5	3
	9	1	0	0	0	1	2	V3	2
	10	0	1	0	1	0	2	V25	7
	Σ	4	4	4	4	4	20		71

**Tablica 4. Primjer rasporeda narudžbi**

### 7.2.1. Ulazni podaci

Kako bi se dobio traženi izlaz, potrebno je definirati ulazne podatke za algoritam. Ulazni podaci za ovaj problem bit će prodavaonice Konzuma, broj stavaka te broj narudžbi tjedno za svaku od njih.

Za početak je iz procjena prodaje potrebno izračunati koliko se stavaka kreira tjedno po prodavaonicama na razini skladišta. Stavka označava kombinaciju prodavaonica – artikl, ali ne sadrži informaciju o broju TP.

Iz podataka o procjeni prodaje računat će se vjerojatnost da se određena stavka taj dan pojavi u narudžbi. Ukoliko je, na primjer, procjena prodaje za taj dan 80, a jedno TP ima 100 komada proizvoda X, onda je vjerojatnost pojave stavke proizvoda X za taj dan 0,8. To znači da će se vjerojatno poslati narudžba za taj dan, ali će ostati određena količina zalihe proizvoda X koja se treba uzeti u obzir kod računanja vjerojatnosti pojave stavke za sljedeći dan. Vjerojatnosti mogu poprimiti samo vrijednosti  $< 1$  ili 1.

proizvod X	P	U	S	Č	P	S	N
broj komada	0,7	2,5	3,3	1,5	5	7	0,6
	$\Sigma$	20,6					
1 TP(X) = 30 kom							
P(X) = 0,687							
proizvod Y	P	U	S	Č	P	S	N
broj komada	5	28	32	18	45	87	42
	$\Sigma$	257					
1 TP(Y) = 50 kom							
P(Y) = 1							
Prodavaonica	Artikl	Stavka					
1	X	0,687					
1	Y	1					
1	Z	...					

**Tablica 5. Simulacija vjerojatnosti pojave pojedine stavke u tjednoj narudžbi**

Tablica 5. prikazuje primjer simulacije vjerojatnosti pojave stavke za artikle X i Y u tjednoj narudžbi. Nakon što su u tjednom forecastu zbrojene dnevne količine za određeni artikl, računa se vjerojatnost da će se ta stavka pojaviti u narudžbi za taj tjedan, tj. jednostavno se računa da li je predviđena prodaja za taj tjedan dovoljna da se dostavi barem 1 TP.

Vjerojatnosti pojave stavki u narudžbi računaju se kako bi se odredio broj dostava tjedno za svaku od prodavaonica. Optimizacijom se došlo do korigiranog broja narudžbi u danima na tjednoj bazi, što znači da je maksimalan mogući broj dostava tjedno 5. Iskustvenom metodom je pronađen optimalan broj stavaka za jednu narudžbu. Kao drugi kriterij uzeta je površina skladišta svake od prodavaonica pa će se tako primjerice u prodavaonicu s malim skladištem, a velikim prometom dostava vršiti 5 umjesto 4 puta tjedno.

### ***7.2.2. Rangiranje mogućih varijanti rasporeda i rangiranje prodavaonica prema važnosti***

Jedan od glavnih kriterija dodjeljivanja rasporeda bit će rang varijante dostava. Kao što je već objašnjeno, ovisno o potrebnom broju narudžbi tjedno računaju se moguće tjedne varijante rasporeda, koje je potom potrebno rangirati. Veći rang će dobiti ona varijanta koja prodavaonici osigurava ujednačeniju opskrbu robom tako da intervali između dostava budu podjednake duljine. Prema iskustvu se zna da je bolji raspored dostava onaj kod kojega između dostava prođe jednako vrijeme. Primjerice, ako se dostava vrši dvaput tjedno, idealno je da između svake dostave prođe tri ili četiri dana. Takva bi dostava bila kombinacija ponedjeljak i četvrtak ili ponedjeljak i petak.

Budući da se svim prodavaonicama ne mogu dodijeliti najbolji rasporedi, osim rasporeda trebaju se rangirati i same prodavaonice prema njihovoj važnosti. Važnost prodavaonice očituje se u njezinom prometu, veličini, tipu (prodavaonica u susjedstvu, super ili maxi), protoku kupaca i slično. Važnije prodavaonice u većoj mjeri sudjeluju u stvaranju profita te se zbog toga takvima daje prednost kod dodjele rasporeda dostava.

Ovisno o rangi važnosti određene prodavaonice bit će joj dodijeljen bolji ili manje dobar raspored dostave. Osim maksimiziranja ukupne sume ranga rasporeda, potrebno je uzeti u obzir i kriterij ranga prodavaonica pa se prema tome treba definirati i funkcija cilja. Nije dovoljno dodijeliti što više dobrih rasporeda, već voditi računa o tome da se najvažnijim prodavaonicama

dodijeli najbolji mogući raspored, iako se time možda žrtvuje dodjela lošijeg rasporeda nekoj od prodavaonica s manjim prometom, ukoliko je ukupna suma kao funkcija cilja maksimalna.

### **7.2.3. Balansiranje količine rada na skladištu**

Osim rangiranja varijanti rasporeda i rangiranja prodavaonica, drugi kriterij optimizacijskog modela dodjele rasporeda bit će balansiranje količine rada na skladištu.

Varijacije po danima ne smiju biti veće od  $\pm 10\%$ , što znači da se rasporedi dostava moraju kreirati sukladno s ovim ograničenjem.

Prema ovom kriteriju idealan raspored značio bi dnevna odstupanja od 0%, tj. da se svakim danima provede jednak broj dostava. Budući da se narudžbe kreiraju s optimalnim brojem stavaka, svaka od njih znači podjednako opterećenje za skladište te se balansiranje treba provesti samo kontrolom broja dostava svaki dan u tjednu.

### **7.2.4. Izlazni podaci**

*Output* rješenja predstavljat će dodijeljeni raspored dostava po prodavaonicama uz zadovoljene određene uvjete. Kod kreiranja rasporeda uzet će se u obzir sumarni broj stavaka po danu za svaku prodavaonicu.

Konačno, algoritam će prema ulaznim podacima raspoređivati dostave te davati informacije o tome koji se dan vrši dostava u određenu prodavaonicu. Tako će obujam posla biti uvijek jednak, bez obzira na promjene zbog blagdana ili nečeg drugoga. Također, rad na skladištu trebao bi ovim promjenama biti ujednačeniji, a odstupanja po danima u tjednu što manja.

## **7.3. Rješenje problema**

### **7.3.1. Funkcija cilja**

Problem dodjeljivanja rasporeda prodavaonicama treba postaviti u obliku funkcije cilja koju je potrebno maksimizirati, odnosno u ovom slučaju minimizirati.

Za svaku kombinaciju prodavaonice  $i$  dana dostave uvodi se po jedna binarna varijabla:  $X_{ij} \in \{0,1\}$ , koja će poprimiti vrijednost 1 ukoliko se u prodavaonicu  $i$  dostava vrši na dan  $j$ , dok će u suprotnom ona poprimiti vrijednost 0.

Broj prodavaonica  $i$  određen je brojem Konzumovih prodavaonica koje u tom trenutku posluju, a prema [9] on će biti otprilike 600.

Broj dana  $j$  kojima se vrši dostava poprima brojeve od 1 do 5 budući da se dostava vrši samo radnim danima.

Funkcija cilja treba biti opisana tako da se njenom minimizacijom dobije optimalna kombinacija varijanti, tj. da varijante imaju što bolji, odnosno niži rang u ukupnoj sumi. Također, dobivena kombinacija varijanti treba zadovoljiti i zahtjev na balansiranosti rada na skladištu. To znači da svi dani na skladištu trebaju imati približno jednako opterećenje.

Treba uzeti u obzir da kombinacije ovise o broju narudžbi tjedno prema  $\binom{5}{x}$ . Ukupan broj mogućih varijanti rasporeda iznositi će:

$$\binom{5}{1} + \binom{5}{2} + \binom{5}{3} + \binom{5}{4} + \binom{5}{5} = 5 + 10 + 10 + 5 + 1 = 31$$

Svako od 31 varijanti trebat će se dodijeliti rang.

### 7.3.2. Ograničenja

#### 7.3.2.1. Broj dostupnih dana u tjednu za dostavu

Broj dana u tjednu kojima je moguća dostava je 5. To znači da se prema procjenama prodaje i stavkama koje će se pojaviti u narudžbama dostava može razbiti na maksimalno 5 dijelova. Za svaku prodavaonicu, ukupan broj dostava ne smije prelaziti 5:

$$\forall i \sum_j X_{ij} \leq 5$$

#### 7.3.2.2. Fiksne rute dostava

Veliko ograničenje predstavljaju već isplanirane fiksne rute dostava.

To znači da se dodjela rasporeda treba prilagoditi rutama dostava. Budući da postoji ograničeni broj dostupnih dostavnih vozila, on se treba optimalno koristiti.

Kao što je već objašnjeno, budući da Konzum raspolaže s dva logističko-distributivna centra koja opskrbljuju prodavaonice po čitavoj Hrvatskoj, dostava u udaljenija područja ne može se vršiti svakodnevno, nego samo određenim danima. Primjerice, na kvarnerske otoke dostava može biti moguća samo ponedjeljkom, srijedom i četvrtkom pa se prema tome treba složiti raspored dostava u prodavaonice koje se nalaze na tom području. Ovo ograničenje smanjuje broj varijanti budući da je u ovom slučaju broj dana u tjednu kada je moguće dostava smanjena s 5 na 3. Broj varijanti će se sada računati kao  $\binom{3}{x}$ , gdje  $x$  predstavlja broj potrebnih dostava u tjednu.

Za svaku prodavaonicu  $a$ , dostava je moguća samo u  $k$ -om danu:

$$X_{aj} = \begin{cases} 1, & j = k \\ 0, & j \neq k \end{cases}$$

Ovo ograničenje odnosi se na sve prodavaonice  $a$ , koje nalaze na području za koje se dostava odvija  $k$ -im danima.

Isto tako će glasiti ograničenje za sve prodavaonice  $b$ , za koje je dostava moguća samo u  $l$ -om danu te za prodavaonice  $c$ , za koje je dostava moguća samo u  $m$ -om danu itd.

Ograničenja ovog tipa bit će onoliko koliko ima fiksnih ruta dostava.

### 7.3.2.3. Intervali između dostava

Intervali između dostava moraju biti ujednačeni, prvenstveno zbog ograničenih kapaciteta na skladištu. Ukoliko prodavaonica zahtjeva dostavu 3 puta tjedno, ta dostava se ne može odvijati npr. ponedjeljkom, utorkom i srijedom budući da između prve i druge dostave prođe samo jedan dan, a između zadnje dostave u tekućem tjednu i prve dostave u sljedećem prođe čak pet dana. U tom bi slučaju razina zaliha u prvoj polovici tjedna bila preko maksimalne, a u drugoj polovici tjedna bi vjerojatno nedostajao velik broj artikala. Zbog toga između dviju dostava treba proći otprilike jednak broj dana. Na taj način osigurava se bolja kontrola zaliha te smanjuju troškovi eventualnog otpisa robe.

Treba postaviti nekoliko ograničenja. Za dostavu jednom tjedno nema ograničenja ovog tipa. Za prodavaonicu u koju se dostava vrši dvaput tjedno određuje se redni broj dana isporuke:

$$dan\_isporuke_{i2} = \sum_j j \cdot X_{i2,j}$$

Za svaku prodavaonicu  $i_2$ , u koju se dostava vrši dvaput tjedno postavlja se ograničenje:

$$\sum_j j_2 \cdot X_{i_2, j_2} - \sum_j j_1 \cdot X_{i_2, j_1} \geq 3, \quad j_1, j_2 = [1, 5]$$

Između prve i druge dostave u tjednu treba proći minimalno tri dana.

Za svaku prodavaonicu  $i_3$ , u koju se dostava vrši triput tjedno postavlja se ograničenje:

$$\sum_j j_3 \cdot X_{i_3, j_3} - \sum_j j_1 \cdot X_{i_3, j_1} \geq 3, \quad j_1, j_2 = [1, 5]$$

Između prve i treće, odnosno zadnje dostave treba proći minimalno tri dana.

Za dostave četiri i pet puta tjedno ne postoji ograničenje budući da se intervali između dostava ne mogu bitno promijeniti.

#### 7.3.2.4. Rang prodavaonice

Važnost određene prodavaonice s obzirom na njen promet i veličinu igra veliku ulogu kod raspoređivanja dostava. Budući da važnije prodavaonice imaju veći udio u stvaranju profita, njima se treba dodijeliti najbolji mogući raspored kako bi one imale na raspolaganju uvijek dovoljnu količinu zaliha, ali i kvalitetniju te svježiju robu.

$$X_i \begin{cases} R_1, & V_i = [1, 3] \\ R_2, & V_i = [1, 5] \\ R_3, & V_i = [1, 7] \\ R_4, & V_i = [1, 10] \\ & \dots \\ R_{10}, & V_i = [1, 31] \end{cases}$$

Svaka prodavaonica može se rangirati od  $R_1$  do  $R_{10}$ , tako da  $R_1$  označava najveću važnost, a  $R_{10}$  najmanju važnost prodavaonice  $X_i$ . Ovisno o rangui koji ima određena prodavaonica, varijanta rasporeda koja joj može biti dodijeljena mora biti unutar predviđenog intervala.



---

## 8. ZAKLJUČAK

Nakon detaljne analize trenutnih procesa dodjeljivanja rasporeda dostava u prodavaonice Konzuma te definiranja željenih rezultata, uz matematičku metodu linearnog programiranja sagledan je problem. Uz proučavanje temeljnih procesa SCM-a lakše je razumjeti problem te postaviti ograničenja koja moraju biti zadovoljena ponuđenim rješenjem.

Konzum već ima razvijen izvrstan sustav praćenja i procjene prodaje koji generira veliku količinu podataka. Ti su podaci relevantni za kreiranje rasporeda dostava, ali je zbog obujma posla kojeg zahtijeva taj proces potrebno stvoriti algoritam koji će samostalno na temelju određenih ulaznih podataka kreirati optimalnu kombinaciju rasporeda.

Linearno programiranje s cjelobrojnim binarnim varijablama predstavlja područje unutar kojega se problem može proučavati. Potrebno je jasno definirati ciljeve i ograničenja kako bi se omogućila daljnja analiza te traženje prikladnog modela i algoritma za rješavanje ovog problema.

---

**LITERATURA**

- [1] Joshi, Parkhi, Sharma, Gupta: A Study of Evolution and Future of Supply Chain Management, AIMS International Journal of Management 9(2), 2015.
- [2] <https://scm.ncsu.edu/scm-articles/article/what-is-supply-chain-management-scm>
- [3] <https://www.scmglobe.com/five-supply-chain-drivers/>
- [4] <https://profitiraj.hr/lanac-opskrbe-kao-konkurentska-prednost/>
- [5] Predavanja Tehnička logistika, prof.dr.sc. Goran Đukić, FSB, Zagreb, 2014.
- [6] Krpan, Maršanić, Jedvaj: Upravljanje zalihama materijalnih dobara i skladišno poslovanje u logističkoj industriji, Tehnički glasnik 8, 2014.
- [7] Predavanja Poslovna logistika, doc.dr.sc. Ivan Kovač, Ekonomski fakultet, Zagreb
- [8] <http://www.businessmanagementideas.com/marketing/physical-distribution/physical-distribution-definition-objectives-importance-and-components-marketing/17992>
- [9] <https://www.konzum.hr/>
- [10] <http://www.agrokor.hr/hr/brendovi/konzum/>
- [11] Krešimir Križanović, Cjelobrojno programiranje u nekim problemima raspoređivanja, FER, Zagreb, 2005.
- [12] Ivan Ćorić, Raspoređivanje s ograničenjima u okolini nesrodnih strojeva, Zagreb, 2016.
- [13] de Villers, M.-É.: Dictionnaire de la gestion de la production et des stocks, Québec Amérique/Presses HEC, 1993.
- [14] Predavanje o MPS, ISLI, 2016.
- [15] Liangliang Fu: Coordination of production and distribution scheduling, Université Paris Dauphine - Paris IX, 2014.
- [16] Jayant Rajgopal, Ph.D., P.E.: Supply Chains: Definitions & Basic Concepts, University of Pittsburg, 2016.
- [17] <https://www.michiganstateuniversityonline.com/resources/supply-chain/is-logistics-the-same-as-supply-chain-management/>
- [18] <https://blog.procurify.com/2014/10/28/difference-procurement-supply-chain-management/>
- [19] <http://www.biz-development.com/SupplyChain/6.20.6.supply-chain-management-order-processing.htm>

---

## **PRILOZI**

I. CD-R disc